农业干旱卫星遥感监测与预测研究进展

韩　东，王鹏新*，张　悦，田惠仁，周西嘉

（中国农业大学 信息与电气工程学院，北京 100083）

摘　要：干旱是影响农业生产的主要气候因素。传统的农业干旱监测主要是基于气象和水文数据，虽然能提供监测点上较为精确的干旱监测结果，但是在监测面上的农业干旱时，仍存在一定的局限。遥感技术的快速发展，尤其是目前在轨的卫星传感器感测的电磁波段涵盖了可见光、近红外、热红外和微波等波段，为区域尺度农业干旱监测提供了新的手段。充分利用卫星遥感数据获得的丰富地表信息进行农业干旱监测和预测具有重要的研究意义。本文从遥感指数方法、土壤含水量方法和作物需水量方法三个方面阐述了基于卫星遥感的农业干旱监测研究进展。农业干旱预测是在干旱监测的基础上进行时间轴的预测，本文在总结干旱监测进展的基础上，进一步简述了以干旱指数方法和作物生长模型方法为主的农业干旱预测研究进展。

关键词：卫星；遥感；农业干旱；作物生长模型；监测；预测

中图分类号：S423;TP79　　**文献标志码：**A　　**文章编号：**202104-SA002

引用格式：韩东, 王鹏新, 张悦, 田惠仁, 周西嘉. 农业干旱卫星遥感监测与预测研究进展[J]. 智慧农业(中英文), 2021, 3(2): 1-14.

HAN Dong, WANG Pengxin, ZHANG Yue, TIAN Huiren, ZHOU Xijia. Progress of agricultural drought monitoring and forecasting using satellite remote sensing[J]. Smart Agriculture, 2021, 3(2): 1-14. (in Chinese with English abstract)

1　引　言

干旱是一种频繁发生的自然灾害现象。Wilhite和Glanze[1]将干旱划分为气象干旱、水文干旱、农业干旱和社会经济干旱四种类别。气象干旱通常表示某一特定时间段内降水量偏离正常降水量的程度。水文干旱表示干旱期对地表或地下水文的影响。农业干旱是指某一特定时期内土壤水分不能满足农作物正常生长的需求，其表达的是干旱现象对农业生产的影响程度。社会经济干旱指某一特定时期内，由于自然界水分供应不足而对人类社会经济生活产生影响的现象，通常与气象干旱、水文干旱和农业干旱有关。

农业干旱作为常见的农业灾害之一，主要表现为土壤水分无法正常供给作物生长所需的水分，影响作物对水分的吸收利用，进而影响作物产量[2]。干旱胁迫对于作物的各生理参数具有不同程度的影响，主要表现为抑制作物根系对水分和养分的吸收，抑制光合作用、蒸腾作用等生理功能，严重时甚至导致作物枯萎死亡[3]。目前已经有大量方法来监测和表征农业干旱，主要包括基于地面站点测量气象、水文数据的方法和基于

收稿日期：2021-04-15　修订日期：2021-05-25

基金项目：国家自然科学基金面上项目（41871336）

作者简介：韩 东（1994—），男，博士研究生，研究方向为农业定量遥感。E-mail：hd5877@cau.edu.cn。

*通讯作者：王鹏新（1965—），男，博士，教授，研究方向为定量遥感及农业应用。电话：010-62737622。E-mail：wangpx@cau.edu.cn。

遥感数据的方法[4]。地面站点测量的数据，比如降水和温度等，在局部或区域尺度上的适用性主要取决于地面站点的布设密度和空间分布，这就使得数据结果在区域尺度的应用受到限制[5]。随着卫星传感器的不断发展，获取大范围、长时间序列地表监测信息的能力逐渐提高。卫星传感器可以感知土壤、植被、温度等地表信息，将这些信息纳入到干旱评估过程是大范围农业干旱监测的有效方法[6,7]。

随着现代社会经济的快速发展，农业管理部门不仅要求对农业干旱等灾害做出精准的实时监测，还要求能实现农业干旱的动态预警。在这些方面，卫星遥感可以提供良好的数据源。本文从基于遥感指数、土壤含水量和作物需水量方法三方面阐述农业干旱遥感监测研究进展，并在此基础上简述基于遥感干旱指数和基于作物生长模型方法的农业干旱预测研究进展。

2　农业干旱遥感监测研究进展

在区域尺度，基于遥感技术的农业干旱监测方法能综合考虑植被和土壤层信息，因此被广泛应用于农业干旱监测研究[8]。植物生长所需的水分来源于土壤，土壤水分的亏缺直接影响植物的生长发育，因此通过遥感手段监测土壤含水量也能间接感知干旱发生程度[9,10]。对于农业而言，作物在生长季前的地表覆盖主要是裸土，而在生长季内则主要是植被，此时植被覆盖下的土壤水分监测精度受植被层的影响较大，监测难度较高。因此，多源遥感数据结合被广泛应用于区域尺度的土壤含水量和农业干旱监测[11]。此外，农业干旱程度还取决于作物对干旱胁迫的反应状况。这是由于不同作物对干旱胁迫的响应程度不同，且同一作物在不同生育期对干旱胁迫的响应也具有差异化的表现[12,13]。因此，将作物需水作为出发点，以作物生长模型为载体，结合遥感对地观测技术，对作物生育期的水分胁迫进行客观、详细地描述是农业干旱监测的重要研究方向。

2.1 基于遥感指数的农业干旱监测

在基于遥感的农业干旱监测方法中，大量研究利用可见光和热红外波段反演的遥感干旱指数估测区域尺度干旱程度，例如，植被干旱指数中的植被状态指数（Vegetation Condition Index，VCI）[14]和温度干旱指数中的温度条件指数（Temperature Condition Index，TCI）[15]。在此基础上，研究人员基于遥感反演的归一化植被指数（Normalized Difference Vegetation Index，NDVI）和地表温度（Land Surface Temperature，LST）的散点图呈三角形区域分布的特征，提出了综合植被-温度干旱指数中条件植被温度指数（Vegetation Temperature Condition Index，VTCI）的干旱监测方法[16]，并将其广泛地应用于区域性的农业干旱监测[17,18]。此外，介于可见光和热红外之间的短波红外波段对作物叶片含水量更敏感，因此通过短波红外波段建立的水分干旱指数也被用来监测作物的干旱胁迫状态，进而评估农业干旱程度，如归一化差异水分指数（Normalized Difference Water Index，NDWI）[19]，短波红外水分胁迫指数（Shortwave Infrared Water Stress Index，SIWSI）[20]。在更长波长的电磁波谱段，基于微波遥感建立的微波干旱指数也被用来进行农业干旱监测。例如，Esch等[21]基于ERS-SAR数据，提出了农作物覆盖区域的土壤含水量监测指数（Soil Moisture Index，SMI），研究得出SMI能较好地估计近地表土壤含水量的变化情况。表1列出了主要的遥感干旱监测指数。

表1　主要干旱监测遥感指数

Table 1　Major remote sensing indices for drought monitoring

类型	中文名称	英文名称	英文缩写	定义
植被干旱指数	归一化植被指数	Normalized Difference Vegetation Index	NDVI	NDVI=(NIR−R)/(NIR+R)　（1）

续表 1

类型	中文名称	英文名称	英文缩写	定义
	增强植被指数[22]	Enhanced Vegetation Index	EVI	$EVI=2.5\times(NIR-R)/(NIR+6\times R-7.5\times B+1)$ (2)
	条件植被指数[14]	Vegetation Condition Index	VCI	$VCI=(NDVI_i-NDVI_{min})/(NDVI_{max}-NDVI_{min})\times 100$ (3)
	距平植被指数[23]	Anomaly Vegetation Index	AVI	$AVI=NDVI_i-NDVI_{mean}$ (4)
	垂直干旱指数[24]	Perpendicular Drought Index	PDI	$PDI=1/((M^2+1)^{-1/2})\times(R+M\times NIR)$ (5)
温度干旱指数	条件温度指数[15]	Temperature Condition Index	TCI	$TCI=(T_{B\ max}-T_{B\ i})/(T_{B\ max}-T_{B\ min})\times 100$ (6)
	归一化温度指数[25]	Normalized Difference Temperature Index	NDTI	$NDTI=(LST_\infty-LST_i)/(LST_\infty-LST_0)$ (7)
综合植被-温度干旱指数	植被健康指数[26]	Vegetation Health Index	VHI	$VHI=\lambda\times VCI+(1-\lambda)\times(1-TCI)$ (8)
	温度植被干旱指数[27]	Temperature Vegetation Dryness Index	TVDI	$TVDI=(T_s-T_{s\ min})/(a+b\times NDVI-T_{s\ min})$ (9)
	条件植被温度指数[16]	Vegetation Temperature Condition Index	VTCI	$VTCI=(LST_{NDVIi\ max}-LST_{NDVIi})/(LST_{NDVIi\ max}-LST_{NDVIi\ min})$ (10) $LST_{NDVIi\ max}=a+b\times NDVI_i$ (11) $LST_{NDVIi\ min}=a'+b'\times NDVI_i$ (12)
水分干旱指数	水分亏缺指数[28]	Water Deficit Index	WDI	$WDI=1-ET/PET$ (13)
	干旱严重程度指数[29]	Drought Severity Index	DSI	$DSI=(Z-Z_{mean})/\sigma_Z$ (14) $Z=(NDVI-NDVI_{mean})/\sigma_{NDVI}+(ET/PET-(ET/PET)_{mean})/\sigma_{ET/PET}$ (15)
	归一化差异水体指数[19]	Normalized Difference Water Index	NDWI	$NDWI=(R-SWIR)/(R+SWIR)$ (16)
	短波红外水分胁迫指数[20]	Shortwave Infrared Water Stress Index	SIWSI	$SIWSI=(SWIR-NIR)/(SWIR+NIR)$ (17)
	水分胁迫指数[30]	Mositure Stress Index	MSI	$MSI=SWIR/NIR$ (18)
	简单比值水分指数[31]	Simple Ratio Water Index	SRWI	$SRWI=(SWIR-NIR)/(SWIR+NIR)$ (19)
	归一化多波段干旱指数[32]	Normalized Multi-band Drought Index	NMDI	$NMDI=(NIR-(SWIR1-SWIR2))/(NIR+(SWIR1+SWIR2))$ (20)
	可见光和短波红外干旱指数[33]	Visible and Short-wave Infrared Drought Index	VSDI	$VSDI=1-((SWIR-B)+(R-B))$ (21)
微波干旱指数	微波植被指数[34]	Microwave Vegetation Indice	MVI	$MVI=(T_{Bv}(f_2)-T_{Bh}(f_2))/(T_{Bv}(f_1)-T_{Bh}(f_1))$ (22)
	温度微波植被干旱指数[35]	Temperature Microwave Vegetation Index	TMVDI	$TMVDI=(LST_i-LST_{min})/(a+b\times MVI-LST_{min})$ (23)
	土壤湿度指数[21]	Soil Moisture Index	SMI	$SMI=(\sigma^0-\sigma^0_{dry})/(\sigma^0_{wet}-\sigma^0_{dry})\times 100$ (24)

注：R、B、NIR、SWIR分别代表红光波段、蓝光波段、近红外波段和短波红外波段（SWIR1和SWIR2分别为两个不同的短波红外波段）；$NDVI_{max}$、$NDVI_{min}$、$NDVI_{mean}$分别代表NDVI最大值、最小值和平均值；LST_i代表地表温度，LST_∞和LST_0分别代表特定气象条件和地表阻抗下的地表温度上限（干条件）和下限（湿条件）；$T_{B\ i}$代表地表亮温，$T_{B\ max}$和$T_{B\ min}$分别代表地表最大亮温和最小亮温；a、b、a'、b'、M、λ分别为待定系数；ET和PET分别代表蒸散量和潜在蒸散量；$\sigma_{ET/PET}$和σ_Z分别为ET/PET和Z的标准差；f_1和f_2分别为参与指数计算的两个波段的频率；$T_{Bv}(f_i)$ 和$T_{Bh}(f_i)$ 分别代表某一波段的垂直极化亮度温度和水平极化亮度温度；σ^0为雷达后向散射系数，σ^0_{wet}、σ^0_{dry}分别代表干条件和湿条件下的雷达后向散射系数

2.2 基于土壤含水量的农业干旱监测

2.2.1 可见光-热红外数据反演土壤含水量

农业干旱遥感监测的重要途径之一是间接监测土壤含水量。在作物季前，地表覆盖主要是裸土。在监测土壤含水量时，较早的研究主要分析相关遥感干旱指数与实测土壤含水量间的相关性，进而建立两者之间的线性关系。例如，Ghulam等[24]根据植被在红-近红波段的光谱空间特征提出了垂直干旱指数（Perpendicular Drought Index，PDI），并发现该指数与地表实测0～20 cm土壤深度的土壤水分具有较好的相关性，能有效监测裸土区域的干旱状况。此外，热红外遥感也被广泛应用于土壤含水量的监测。热红外遥感反演土壤含水量的一个重要方法是基于土壤热惯量法。大量实验表明，土壤热惯量与土壤水分的变化密切相关。土壤热惯量越大，其温度的变化幅度越小。通过监测土壤温度在某个时间段内的变化程度可以定量地推导出热惯量与土壤含水量之间的关系。对于同一土壤介质，土壤热惯量的表达式为：

$$P = \sqrt{k c \rho} \tag{25}$$

其中，P为土壤热惯量，J/（$m^2 \cdot s^{1/2} \cdot K$）；k为土壤导热系数，J/（m·s·K）；ρ为土壤密度，kg/m^3；c为土壤比热容，J/（kg·K）。通过建立土壤热惯量与土壤水分间的回归模型，可以间接有效地监测较小区域内的土壤水分状况。热惯量法适用于裸土区的土壤含水量反演，但在植被覆盖区域的反演精度较差。刘振华和赵英时[36]在植被覆盖区域将地表潜热通量和显热通量引入到热惯量模型中，从而使热惯量方法的适用范围由裸地扩展到植被覆盖区域，并提高了土壤水分的监测精度。吴黎等[37]提出一种改进的表观热惯量计算模型，并基于该模型计算了不同植被覆盖和不同实验区土壤含水量下的热惯量值，结果表明该模型在植被覆盖度较低的情况下（NDVI≤0.35）具有较高的土壤含水量监测精度。

在作物生长季内，植被覆盖程度较高，此时基于可见光-热红外遥感数据反演的遥感干旱指数与土壤水分具有密切关系。相关研究通过分析干旱指数与实测土壤含水量间的相关性，进而建立两者之间的回归模型，并将其应用于作物覆盖下的土壤含水量的反演。例如，Sun等[38]分析了中国关中平原土壤表层水分与VTCI之间的相关性，结果表明，在冬小麦生长季，旬尺度的VTCI与0～10 cm和0～20 cm土壤深度土壤水分之间均存在显著的线性相关性。

虽然VTCI与土壤水分间的较强相关性可以使得VTCI直接用来反演土壤含水量，但VTCI作为综合植被-温度干旱指数的一种，要想较为准确地确定VTCI在某一应用区域的冷热边界却并不容易。杨永民等[39]使用ASTER数据对比了基于TVDI方法和基于蒸散比/潜在蒸散比方法的土壤含水量反演结果，认为虽然TVDI方法简单易用且不需要额外的气象数据，但是区域干、湿的变化会导致其特征空间干、湿边界的确定出现误差，进而为土壤水分估算引入误差，而基于蒸散比/潜在蒸散比的土壤水分估算方法会在一定程度改善TVDI方法估算的经验性，提高土壤水分的反演精度。为了降低在构建植被-温度综合干旱指数时，冷、热边界确定困难带来的土壤含水量反演难题，研究人员从另一角度出发，不再考虑地表温度（热红外数据）对遥感干旱监测的影响，直接基于可见光和近红外遥感数据来反演土壤含水量。例如，Ghulam等[40]在PDI的基础上考虑了植被层的影响并引入植被覆盖度，提出了改进型的垂直干旱指数（Modified Perpendicular Drought Index，MPDI），该指数在植被生长中后期与地表实测0～20 cm土壤深度的土壤含水量具有较高的相关性，可有效监测作物生长季内的干旱程度。

2.2.2 微波数据反演土壤含水量

相比可见光和热红外谱段，合成孔径雷达卫星发射的电磁波对地表水分的变化更为敏感。在作物季前，通过分析雷达后向散射信息与地面实测土壤含水量之间的相关性，可基于经验模型的方法反演裸土区土壤含水量，在此基础上，基于

机器学习方法的土壤含水量估计被广泛研究[41]。此外，一些基于半经验模型和物理模型的方法也被广泛研究并用于反演裸土区的土壤含水量，并取得了较为理想的结果[42, 43]。然而，在作物生长季内，监测有植被覆盖的农作物种植区域的土壤含水量时，由于雷达信号受到土壤层和作物冠层的混合影响，增加了土壤含水量的监测难度。为解决这一问题，研究人员通过引入雷达散射模型，消除植被层对雷达信号的干扰，进而提高土壤含水量的反演精度。以MIMICS模型（Michigan Microwave Canopy Scattering Model）为代表的植被散射模型被广泛应用于土壤含水量的反演研究，并取得了较为理想的结果[44,45]。然而，由于MIMICS模型对植被层的刻画较为细致，导致其模型结构较为复杂，一般只适用于高大植被覆盖下的土壤含水量反演[46]。对于农作物来说，其植被层一般较为低矮，内部结构简单，因此可基于简化的植被贡献模型来进行土壤含水量反演。在此基础上，水云模型（Water Cloud Model，WCM）被提出，它简化了植被层与土壤层之间复杂的雷达散射效应，并假定植被层是均匀介质且定义了一个参数来描述植被层的特征[47]。因此，该模型适用于农作物覆盖下的土壤含水量反演。目前，在基于水云模型反演农作物覆盖下的土壤含水量研究中，以雷达卫星数据与光学卫星数据相结合的研究居多[48,49]。其中，光学卫星数据一般被用来反演水云模型中描述植被层的特征参数。考虑到光学遥感数据易受云雾天气的影响，导致其在作物生育期内的获取具有不稳定性。Han 等[50]将WCM与一个简单的产量估计（Simple Algorithm For Yield estimate，SAFY）模型结合，利用Sentinel-2卫星数据反演的叶面积指数（Leaf Area Index，LAI）作为SAFY模型的状态变量并模拟了冬小麦生育期内水云模型中植被描述参数（LAI）的日变化，有效地解决了由于光学数据可用性差造成的水云模型中植被描述参数不能准确描述雷达卫星过境时地表植被状态的问题，从而提高了土壤含水量反演的精度。表2列出了微波遥感反演土壤含水量的主要模型。

表2　基于微波遥感的土壤水分反演主要模型

Table 2　Major soil moisture retrieval models based on microwave remote sensing

适用范围	类型	模型	英文全称
裸土	半经验模型[42]	Oh	/
	半经验模型[51]	Dubois	/
	物理模型[52]	GOM	Geometrical Optics Model
	物理模型[53]	POM	Physical Optics Model
	物理模型[54]	SPM	Small Perturbation Model
	物理模型[55]	SSA	Small Slope Approximation
	物理模型[43]	IEM	Integral Equation Model
植被覆盖	半经验模型[47]	WCM	Water Cloud Model
	物理模型[44]	MIMICS	Michigan Microwave Canopy Scattering

土壤水分的变化会影响土壤介电常数的大小，使得微波比辐射率随之发生变化，从而导致被动微波传感器记录的地表亮温发生变化。因此，可通过被动微波遥感记录地表亮温来监测土壤的热辐射，从而间接监测土壤含水量。即首先通过辐射传输模型建立亮温与土壤介电常数间的关系，然后通过介电混合模型建立土壤介电常数与土壤含水量间的关系，最后即可实现土壤含水量的反演[56]。Mo 等[57]提出的t-w模型是大多数辐射传输模型的基础，该模型是零阶辐射传输模型，包含两个参数，一个是植被光学厚度（Vegetation Optical Depth，VOD），另一个是单次散射反照率。针对植被覆盖下的土壤含水量反演，一个关键的环节是有效估计VOD参数。研究发

现，通过建立植被含水量与VOD间的经验线性关系可以估计VOD[58]。因此，利用可见光-近红外遥感数据反演与植被含水量相关的植被指数可以间接实现VOD的估计。此外，也有研究尝试综合多因子数据建立亮温数据与土壤水分间的回归模型反演地表土壤含水量[59]。随着被动微波传感器的快速发展和广泛应用，使用多频率、多角度的双极化亮温数据可降低以往利用单传感器数据反演土壤含水量时模型的不确定性。被动微波传感器相比主动微波传感器普遍具有较大的幅宽，因此适合于全球或区域尺度的土壤水分监测。表3列出了主要的基于微波遥感反演的土壤水分含量产品。其中，基于被动微波遥感数据的土壤水分含量产品较多，在将被动微波遥感数据与主动微波遥感数据相结合后，其反演的土壤水分含量产品的空间分辨率可由约30 km提高到约3 km。

表3 主要的基于微波遥感的土壤水分含量产品

Table 3 Major soil moisture products based on microwave remote sensing

卫星	波段	空间分辨率/km	数据集时段
AQUA[60]	X	25	2002.6～2011.9
GCOM-W1[61]	X	25	2012.7至今
FY-3B/C[62]	X	25	2011.7至今
MetOp-A/B[63]	C	25	2007.1至今
SMOS[64]	L	25	2009.11至今
SMAP[65]	L	36	2015.3至今
SMAP/Sentinel-1[66]	L/C	3	2015.3至今

2.3 基于作物需水量的农业干旱监测

2.3.1 基于作物冠层含水量的农业干旱监测

通过监测作物对水分需求的变化情况可有效反映当前农业干旱程度。监测作物水分需求的直接手段是监测作物冠层含水量。最简单的方法是通过建立相关光谱指数与植被冠层含水量之间的回归模型进行植被含水量的反演[67]。例如，Gao[68]基于NDWI建立了植被冠层水分遥感估测模型并取得了较好的结果。随着机器学习算法的广泛应用，研究人员通过直接建立多个光谱波段与植被含水量间的回归模型可充分挖掘遥感影像的多维光谱特征，有效提高植被含水量的反演精度。作物受到水分胁迫会使其冠层温度发生变化，因此结合可见光-热红外数据监测作物的冠层含水量变化情况对评估农业干旱程度具有重要意义。Gerhards等[69]对基于多光谱/高光谱热红外遥感的作物水分胁迫监测进行了详细总结。此外，微波数据也被逐渐应用到植被含水量的反演研究中。一些研究尝试结合光学与微波遥感数据进行作物冠层含水量的反演[70]。与基于统计模型的冠层含水量反演方法相比，基于辐射传输模型的作物水分监测方法更具机理性。以往研究中较为常用的辐射传输模型有PROSPECT（The Leaf Optical Properties Spectra）叶片模型、SAIL（Scattering by Arbitrarily Inclined Leaves）冠层模型和PROSPECT+SAIL耦合的叶片-冠层模型。吴伶等[71]通过耦合叶片辐射传输模型——PROSPECT模型和冠层辐射传输模型——SAIL模型，并以植被指数NDWI作为优化比较对象来反演植被含水量，有效地提高了植被含水量的反演精度。随着高光谱卫星数据的广泛应用，研究人员将辐射传输模型与高光谱数据相结合，进一步提高了作物含水量的反演精度[72,73]。

2.3.2 基于作物生长模型的农业干旱监测

作物在生长季内受到干旱胁迫的影响会使其生理功能受到抑制，导致其生理参数发生变化，这是遥感技术监测农业干旱的理论依据。作物生长发育受到的水分胁迫程度在相对较大的区域是变化的，而且作物在不同生育阶段受到不同程度的干旱胁迫其生长状况也会不同[12]。在作物相同生育时期，不同程度干旱胁迫下作物生长状况也存在差异。在进行区域尺度农业干旱监测时，遥感数据反演的干旱指数受时空条件的限制，一般具有较低的时间分辨率，然而作物在水分亏缺发生后，较短时间内就会出现缺水生理反应。因此，这些指数可能无法反映作物在关键生长阶段缺水导致的产量损失。而基于作物需水量和土壤供水日步长的干旱指数能更为详细地描述干旱胁

迫对作物生长的影响。在评估水分亏缺对植物生长的影响时，作物生长模型可以捕获作物生理学和水耗竭之间的响应，能够考虑到干旱胁迫对叶片生长过程的影响。因此，相比单独使用遥感干旱指数，作物生长模型与遥感数据相结合进行农业干旱胁迫监测将更具优势。一般来说，基于过程的作物生长模型将作物特性、土壤特性和环境条件对作物生长和产量形成的影响结合起来进行作物生长模拟，可以在不同区域、不同生长季节进行广泛应用[74]。例如，相比四个主要生育期的VTCI，旬尺度的VTCI与土壤含水量之间具有强的相关性且能更全面、准确地反映作物主要生育期内的干旱变化[25]。因此，旬尺度的VTCI可以作为反演土壤水分的变量，并通过间接法将其与作物生长模型相结合，即首先建立VTCI与模型某一中间变量（如土壤含水量）之间的线性关系，然后借助该中间变量进行模型运转。例如，Xie 等[75]利用Landsat卫星数据反演的旬尺度VTCI线性估计土壤含水量，将估算的土壤含水量和Landsat卫星数据反演的LAI作为CERES-Wheat模型同化过程中的观测值，并在冬小麦主要生育期同化LAI和土壤含水量，提高了干旱胁迫的模拟精度。虽然间接法初步解决了将遥感干旱监测结果与作物生长模型结合的问题，然而间接法容易引入外部误差，且在考虑遥感干旱监测结果与作物生长模型间存在的时间尺度异化问题时还较为粗略。

大量研究基于数据同化算法，结合遥感数据与作物生长模型进行农业干旱监测，提高了农业干旱的动态监测水平[74]。虽然一些经典作物生长模型（如DSSAT模型和WOFOST模型）在结构方面具有很强的机理性，均能较为细致地描述作物生长过程，并能对影响作物生长的相关胁迫因子的变化进行动态模拟[76]。但是在用卫星遥感数据结合作物生长模型解决区域尺度的干旱监测问题时，这些模型的应用受到一定程度的限制。主要是因为这类复杂模型需要较多的输入数据，包括详细的农业气象数据、品种数据和田间管理数据等。而这些参数在区域尺度是很难获取的，这就导致模型很难与遥感数据结合进行大范围的农业干旱监测。

相比较为复杂的作物模型，近年来，一些能够模拟作物干旱胁迫状态的结构较为简单的作物生长模型被提出，使得区域尺度的农业干旱遥感监测变得可能，其中比较具有代表性的有AquaCrop模型[77]和SAFY-WB模型[78]。目前，这两种模型得到了研究人员越来越多的关注，在区域尺度研究，特别是遥感数据同化方面，具有很好的应用前景。AquaCrop模型是一个水分驱动模型，可以准确地描述不同水分胁迫条件下主要草本作物的产量与需水量之间的关系。该模型通过模拟作物蒸腾作用，并使用标准化作物水分生产力（Normalized Crop Water Productivity，NCWP）将日蒸腾量转化为作物的日生长量。NCWP的引入使得AquaCrop模型可以在不同地点和生长季节进行应用。SAFY-WB模型由SAFY模型[79]与FAO水平衡模型[80]结合构成。在原始SAFY模型中用来衡量作物受到的干旱胁迫程度的参数因子为一固定值，但实际上作物在生长季内受到的干旱胁迫与农业干旱程度密切相关。在作物生长季内，农业干旱经常是变化的。因此，SAFY-WB模型通过引入动态的水分胁迫系数，能有效模拟作物在生长过程中的干旱胁迫动态变化情况。此外，Silvestro 等[81]分析了AquaCrop模型和SAFY-WB模型在干旱胁迫条件下模拟冬小麦产量的敏感性，发现在区域尺度下，AquaCrop模型在不同缺水环境下的作物生长模拟表现要强于SAFY-WB模型，但相比SAFY-WB模型，其对参数校准的要求更严格。

3 农业干旱预测研究进展

基于卫星遥感预测农业干旱有两种方法，一种方法是在干旱监测的基础上，通过干旱时空预测模型对未来时间段内的农业干旱状况进行模拟；另一种方法是在作物生长模型的基础上，改进其水分胁迫模块，构建作物干旱监测模型，将

遥感观测作为同化干旱胁迫的中间变量，并结合短、中、长期气象数据进行农业干旱预测。

3.1 基于干旱指数的农业干旱预测

基于遥感干旱指数预测农业干旱具有重要研究价值。这类研究主要是以时间序列遥感干旱指数作为输入数据并基于时序分析等方法预测未来时间段内的干旱变化。例如，韩萍等[82]运用求和自回归移动平均（Auto Regressive Integrated Moving Average，ARIMA）模型对VTCI时空序列进行分析建模并开展冬小麦生长季内干旱分析预测，结果表明基于该模型的1～2步预测可以较好地预测区域干旱变化情况。李俐等[83]应用ARIMA模型和季节性求和自回归移动平均（Seasonal Auto Regressive Integrated Moving Average，SARIMA）模型对夏玉米生长季内的VTCI进行建模预测，结果表明ARIMA模型具有比SARIMA模型更高的VTCI预测精度，且基于ARIMA模型的VTCI 1～3步预测在多个年份间具有较稳定的精度表现。

历史干旱数据呈现大数据特征，人工智能算法可有效挖掘历史年份的数据特征，进一步提高干旱预测精度。近年来，研究人员开始基于神经网络和深度学习的方法进行干旱预测，取得了较好的结果[84, 85]。随着遥感技术的快速发展，遥感反演的面上干旱指数本身已具备空间大数据特征，此外随着多卫星传感器的组合使用，遥感干旱指数也具有越来越高的时间维度。目前，针对遥感干旱指数，基于机器学习算法的农业干旱预测研究还较少，这将是未来的一个研究热点。

3.2 基于作物生长模型的农业干旱预测

农业干旱预测的落脚点为预测干旱对作物长势的影响程度。从这一角度考虑，基于作物生长模型的农业干旱预测方法具有重要研究价值。作物生长模型依靠气象数据进行驱动，通过引入未来一段时间内的气象预报数据，可以有效模拟作物在未来时间段的生长状态并预报作物的干旱胁迫状态。此外，将作物生长模拟与农业干旱监测相结合，对作物生长模型进行改进，以实现对农业干旱的监测与预警[86]。例如，吴熠婷等[87]利用天气发生器LarsWG5.5模拟未来时间段内的气象数据并将其输入到校准后的作物生长模型，进而预测气候变化条件下冬小麦产量并评估减产风险。遥感观测可以及时反映地表的瞬时状态，有效监测农业干旱程度。对于上述干旱预测模型而言，引入相关遥感观测量可以进一步提高模型的预测能力。因此，将气象、水利和农业农村部门提供的中长期气象数据作为这些模型的输入数据，运用数据同化技术，耦合遥感观测量（如土壤水分）与模型模拟值，可以有效提高模型的农业干旱预测能力[88, 89]。例如，王治海等[90]基于改进后的ARID CROP模型，利用AMSR-E传感器获取的区域农田水分信息作为模型中间变量，从而预测农业干旱的动态变化，结果表明将遥感观测信息引入改进后的作物生长模型能有效提高冬小麦生长发育的预测能力和区域农业干旱的预测精度。

4 仍需解决的问题与展望

虽然，目前基于卫星遥感数据的农业干旱监测预测研究在很多方面已经取得了大量突破，然而，相关领域的研究还存在一些需要解决的问题。

（1）多个遥感干旱监测指数的结合可提高单个干旱指数的监测误差。目前这种综合考虑作物不同生育期干旱指数的合成指数并不多，也缺乏与作物机理相关的指数。因此，需要结合多种指数，从机理上考虑干旱胁迫的影响因素，开发综合指数提高干旱监测精度。

（2）基于中等空间分辨率遥感数据反演的遥感干旱监测指数已被广泛研究，且被证实能有效表征区域的干旱程度。近年来，随着高等空间分辨率遥感卫星的投入使用，在获取时间序列更高空间分辨率遥感干旱监测指数时，研究人员探索融合中等和高等空间分辨率遥感数据，以得到降尺度后的时间序列遥感干旱监测指数。同时也尝

试基于多个同质遥感数据源，对其包含的数据进行整合，以得到时间序列遥感干旱监测指数。然而，目前融合异质遥感数据的干旱监测指数研究目前总体还偏少，相关方法还比较初步。未来可尝试探索利用深度学习技术深入挖掘异质遥感数据间的特征信息，构建相关干旱监测指数，并建立农业干旱动态监测系统，推动智慧农业发展。

（3）融合多源遥感数据的干旱监测方法能较好地表征植被层和土壤层的综合干旱状态，进而获得较为理想的农业干旱监测结果。在此背景下，不同数据源间的时空一致性问题需要进一步考虑。例如，在以往的研究中对基于水云模型并结合光学和雷达影像反演土壤含水量已经进行了详细的研究和分析，但是在一个相对较大的研究区域，特别是我国南方地区，光学影像在大多数时间内都易受多云天气的影响，数据源的可用性并不是很高，限制了遥感数据的应用。在这种情况下，及时有效地确定水云模型的植被描述参数非常重要，这就需要研究人员考虑不同类型遥感数据源获取日期间的差异对干旱监测结果的影响，目前针对这方面的研究还不是很多。未来可针对这一问题探索使用同系统遥感数据源，例如Sentinel系列卫星搭载了涵盖微波-可见光-热红外的有效载荷，其各个数据源具备相近的空间和时间分辨率，各个数据源间的协同性很高，且具备全球范围的观测能力。因此，可探索利用深度学习方法获取更广泛数据源之间的互补信息，以得到高等空间和时间分辨率的遥感干旱监测结果。

（4）农业干旱作为重要的环境因子对作物生长具有重要影响，在利用数据同化方法将其与作物生长模型结合进行作物产量估测时，现有研究大多采取间接法。为减少外部误差的引入，同时考虑遥感干旱监测结果与作物生长模型间存在的时间尺度异化问题，未来可探索采取直接法将干旱监测结果与作物生长模型相结合，通过引入深度学习方法，同步时间序列干旱监测结果与作物生长模型的时间尺度，针对作物在各个生育时期的生理特点，更为科学地考虑土壤层和植被层水分胁迫对作物生长的阶段化和差异化的影响，从而提高利用作物生长模型的干旱动态监测精度。

5　总　结

卫星遥感技术的快速发展使得针对卫星数据的农业干旱监测研究不断深入，同时也促使基于卫星遥感数据的农业干旱监测逐步市场化。本文以卫星遥感的农业干旱监测为目标，重点对其研究进展进行了阐述，并在此基础上简述了卫星遥感的农业干旱预测研究进展。目前，国产遥感卫星数据已呈现大数据特征，基于人工智能的信息自动获取和解译技术将使得遥感数据能够更加广泛有效地应用于农业干旱监测领域。同时，针对海量遥感数据源，将深度学习技术和作物生长模型有机结合起来，基于数据同化思想，深入探索卫星遥感在农业干旱动态遥感监测方面的潜力，可进一步推动智慧农业的发展。

参考文献：

[1] WILHITE D A, GLANTZ M H. Understanding: The drought phenomenon: The role of definitions[J]. Water International, 1985, 10(3): 111-120.

[2] 刘战东, 张凯, 米兆荣, 等. 不同土壤容重条件下水分亏缺对作物生长和水分利用的影响[J]. 水土保持学报, 2019, 33(2): 117-122.
LIU Z, ZHANG K, MI Z. Effects of water deficit on crop growth and water use under different soil bulk densities[J]. Journal of Soil and Water Conservation, 2019, 33(2): 117-122.

[3] 潘晓迪, 张颖, 邵萌, 等. 作物根系结构对干旱胁迫的适应性研究进展[J]. 中国农业科技导报, 2017, 19(2): 51-58.
PAN X, ZHANG Y, SHAO M, et al. Research progress on adaptive responses of crop root structure to drought stress[J]. Journal of Agricultural Science and Technology, 2017, 19(2): 51-58.

[4] 刘高鸣, 谢传节, 何天乐, 等. 基于多源数据的农业干旱监测模型构建[J]. 地球信息科学学报, 2019, 21(11): 1811-1822.
LIU G, XIE C, HE T, et al. Agricultural drought monitoring model constructing based on multi-source data[J]. Journal of Geo-Information Science, 2019, 21(11): 1811-1822.

[5] 马奕, 白磊, 李倩, 等. 区域气候模式在中国西北地区

气温和降水长时间序列模拟的误差分析[J]. 冰川冻土, 2016, 38(1): 77-88.
MA Y, BAI L, LI Q, et al. The error analysis of the long term air temperature and precipitation in Northwest China simulated by WRF model[J]. Journal of Glaciology and Geocryology, 2016, 38(1): 77-88.
[6] 路中, 雷国平, 马泉来, 等. 基于重构的Landsat8时间序列数据和温度植被指数的区域旱情监测[J]. 水土保持研究, 2018, 25(5): 371-377, 384.
LU Z, LEI G, MA Q, et al. Regional drought monitoring based on reconstructed Landsat 8 data and temperature vegetation index[J]. Research of Soil and Water Conservation, 2018, 25(5): 371-377, 384.
[7] 姚远, 陈曦, 钱静. 遥感数据在农业旱情监测中的应用研究进展[J]. 光谱学与光谱分析, 2019, 39(4): 15-22.
YAO Y, CHEN X, QIAN J. Advance in agricultural drought monitoring using remote sensing data[J]. Spectroscopy and Spectral Analysis, 2019, 39(4): 15-22.
[8] 张有智, 解文欢, 吴黎, 等. 农业干旱灾害研究进展[J]. 中国农业资源与区划, 2020, 41(9): 182-188.
ZHANG Y, XIE W, WU L, et al. Research progress on agriculture drought disaster[J]. Chinese Journal of Agricultural Resources and Regional Planning, 2020, 41(9): 182-188.
[9] 赵春江. 农业遥感研究与应用进展[J]. 农业机械学报, 2014, 45(12): 277-293.
ZHAO C. Advances of research and application in remote sensing for agriculture[J]. Transactions of the CSAM, 2014, 45(12): 277-293.
[10] 张伟杨, 钱希旸, 李银银, 等. 土壤干旱对小麦生理性状和产量的影响[J]. 麦类作物学报, 2016, 36(4): 491-500.
ZHANG W, QIAN X, LI Y, et al. Effect of soil drought on the physiological traits and grain yield of wheat[J]. Journal of Triticeae Crops, 2016, 36(4): 491-500.
[11] 陈仲新, 任建强, 唐华俊, 等. 农业遥感研究应用进展与展望[J]. 遥感学报, 2016, 20(5): 748-767.
CHEN Z, REN J, TANG H, et al. Progress and perspectives on agricultural remote sensing research and applications in China[J]. Journal of Remote Sensing, 2016, 20(5): 748-767.
[12] 姚宁, 宋利兵, 刘健, 等. 不同生长阶段水分胁迫对旱区冬小麦生长发育和产量的影响[J]. 中国农业科学, 2015, 48(12): 2379-2389.
YAO N, SONG L, LIU J, et al. Effects of water stress at different growth stages on the development and yields of winter wheat in arid region[J]. Scientia Agricultura Sinica, 2015, 48(12): 2379-2389.
[13] 张建平, 何永坤, 王靖, 等. 不同发育期干旱对玉米籽粒形成与产量的影响模拟[J]. 中国农业气象, 2015, 36(1): 43-49.
ZHANG J, HE Y, WANG J, et al. Impact simulation of drought at different growth stages on grain formation and yield of maize[J]. Chinese Journal of Agrometeorology, 2015, 36(1): 43-49.
[14] LIU W T, KOGAN F N. Monitoring regional drought using the vegetation condition index[J]. International Journal of Remote Sensing, 1996, 17(14): 2761-2782.
[15] KOGAN F N. Global drought watch from space[J]. Bulletin of the American Meteorological Society, 1997, 78(4): 621-636.
[16] 王鹏新, 龚健雅, 李小文. 条件植被温度指数及其在干旱监测中的应用[J]. 武汉大学学报(信息科学版), 2001, 26(5): 412-418.
WANG P, GONG J, LI X. Vegetation-temperature condition index and its application for drought monitoring[J]. Geomatics and Information Science of Wuhan University, 2001, 26(5): 412-418.
[17] TIAN M, WANG P, KHAN J. Drought forecasting with vegetation temperature condition index using ARIMA models in the Guanzhong Plain[J]. Remote Sensing, 2016, 8(9): 690-708.
[18] ZHOU X, WANG P, TANSEY K, et al. Drought monitoring using the Sentinel-3-based multiyear vegetation temperature condition index in the Guanzhong Plain, China[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 129-142.
[19] GAO B. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space[J]. Remote Sensing of Environment, 1995, 58(3): 257-266.
[20] FENSHOLT R, SANDHOLT I. Derivation of a shortwave infrared water stress index from MODIS near- and shortwave infrared data in a semiarid environment[J]. Remote Sensing of Environment, 2003, 87(1): 111-121.
[21] ESCH S, KORRES W, REICHENAU T, et al. Soil moisture index from ERS-SAR and its application to the analysis of spatial patterns in agricultural areas[J]. Journal of Applied Remote Sensing, 2018, 12(2): ID 022206.
[22] HUETE A, DIDAN K, MIURA T, et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices[J]. Remote Sensing of Environment, 2002, 83(1-2): 195-213.
[23] 陈维英, 肖乾广, 盛永伟. 距平植被指数在1992年特大干旱监测中的应用[J]. 环境遥感, 1994, 9(2): 106-112.

CHEN W, XIAO Q, SHENG Y. Application of the anomaly vegetation index to monitoring heavy drought in 1992[J]. Remote Sensing of Environment (China), 1994, 9(2): 106-112.
[24] GHULAM A, QIN Q, ZHAN Z. Designing of the perpendicular drought index[J]. Environmental Geology, 2007, 52(6): 1045-1052.
[25] MCVICAR T R, JUPP D L B. Using covariates to spatially interpolate moisture availability in the Murray-Darling Basin: A novel use of remotely sensed data[J]. Remote Sensing of Environment, 2002, 79(2): 199-212.
[26] KOGAN F. Droughts of the late 1980s in the United States as derived from NOAA polar-orbiting satellite data[J]. Bulletin of the American Meteorological Society, 1995, 76(5): 655-668.
[27] SANDHOLT I, RASMUSSEN K, ANDERSEN J. A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status[J]. Remote Sensing of Environment, 2002, 79(2): 213-224.
[28] MORAN M S, CLARKE T R, INOUE Y, et al. Estimating crop water deficit using the relation between surface-air temperature and spectral vegetation index[J]. Remote Sensing of Environment, 1994, 49(3): 246-263.
[29] SU Z, YACOB A, WEN J, et al. Assessing relative soil moisture with remote sensing data: Theory, experimental validation, and application to drought monitoring over the North China Plain[J]. Physics and Chemistry of the Earth, 2003, 28(1-3): 89-101.
[30] HUNT E R, ROCK B N. Detection of changes in leaf water content using near-and middle-infrared reflectances[J]. Remote Sensing of Environment, 1989, 30(1): 43-54.
[31] ZARCO-TEJADA P J, USTIN S L. Modeling canopy water content for carbon estimates from MODIS data at land EOS validation sites[C]// International Geoscience and Remote Sensing Symposium. Piscataway, New York, USA: IEEE, 2001: 342-344.
[32] WANG L, QU J. NMDI: A normalized multi-band drought index for monitoring soil and vegetation moisture with satellite remote sensing[J]. Geophysical Research Letters, 2007, 34(20): ID 20405.
[33] ZHANG N, HONG Y, QIN Q, et al. VSDI: A visible and shortwave infrared drought index for monitoring soil and vegetation moisture based on optical remote sensing[J]. International Journal of Remote Sensing, 2013, 34(13-14): 4585-4609.
[34] SHI J, JACKSON T, TAO J, et al. Microwave vegetation indices for short vegetation covers from satellite passive microwave sensor AMSR-E[J]. Remote Sensing of Environment, 2008, 112(12): 4285-4300.
[35] 王永前, 施建成, 刘志红, 等. 微波植被指数在干旱监测中的应用[J]. 遥感学报, 2014, 18(4): 843-867.
WANG Y, SHI J, LIU Z, et al. Application of microwave vegetation index in drought monitoring[J]. Journal of Remote Sensing, 2014, 18(4): 843-867.
[36] 刘振华, 赵英时. 遥感热惯量反演表层土壤水的方法研究[J]. 中国科学D辑：地球科学, 2006, 36(6): 552-558.
LIU Z, ZHAO Y. The research on monitoring of land surface soil moisture by the thermal inertia method in remote sensing[J]. Science in China Series D: Earth Sciences, 2006, 36(6): 552-558.
[37] 吴黎, 张有智, 解文欢, 等. 改进的表观热惯量法反演土壤含水量[J]. 国土资源遥感, 2013, 25(1): 44-49.
WU L, ZHANG Y, XIE W, et al. The inversion of soil water content by the improved apparent thermal inertia[J]. Remote Sensing for Land and Resources, 2013, 25(1): 44-49.
[38] SUN W, WANG P, ZHANG S, et al. Using the vegetation temperature condition index for time series drought occurrence monitoring in the Guanzhong Plain, PR China[J]. International Journal of Remote Sensing, 2008, 29(17-18): 5133-5144.
[39] 杨永民, 邱建秀, 苏红波, 等. 基于热红外的四种土壤含水量估算方法对比[J]. 红外与毫米波学报, 2018, 37(4): 459-467.
YANG Y, QIU J, SU H, et al. Estimation of surface soil moisture based on thermal remote sensing: Intercomparison of four methods[J]. Journal of Infrared and Millimeter Waves, 2018, 37(4): 459-467.
[40] GHULAM A, QIN Q, TEYIP T, et al. Modified perpendicular drought index (MPDI): A real-time drought monitoring method[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2007, 62(2): 150-164.
[41] ALI I, GREIFENEDER F, STAMENKOVIC J, et al. Review of machine learning approaches for biomass and soil moisture retrievals from remote sensing data[J]. Remote Sensing, 2015, 7(12): 221-236.
[42] OH Y, SARABANDI K, ULABY F T. An empirical model and an inversion technique for radar scattering from bare soil surfaces[J]. Transactions on Geoscience and Remote Sensing, 1992, 30(2): 370-381.
[43] FUNG A K, LI Z, CHEN K S. Backscattering from a randomly rough dielectric surface[J]. IEEE Transactions on Geoscience and Remote Sensing, 1992, 30(2): 356-369.
[44] ULABY F T, MCDONALD K, SARABANDI K, et al. Michigan microwave canopy scattering models (MIM-

ICS) [C]// International Geoscience and Remote Sensing Symposium (IGARSS). Piscataway, New York, USA: IEEE. ID 1009.
[45] SONG X, MA J, LI X, et al. First results of estimating surface soil moisture in the vegetated areas using ASAR and hyperion data: The Chinese Heihe River Basin case study[J]. Remote Sensing, 2014, 6(12): 12055-12069.
[46] MENG Q, XIE Q, WANG C, et al. A fusion approach of the improved Dubois model and best canopy water retrieval models to retrieve soil moisture through all maize growth stages from Radarsat-2 and Landsat-8 data[J]. Environmental Earth Sciences, 2016, 75(20): 1377-1391.
[47] ATTEMA E P W, ULABY F T. Vegetation modeled as a water cloud[J]. Radio Science, 1978, 13(2): 357-364.
[48] NOTARNICOLA C, ANGIULLI M, POSA F. Use of radar and optical remotely sensed data for soil moisture retrieval over vegetated areas[J]. IEEE Transactions on Geoscience and Remote Sensing, 2006, 44(4): 925-935.
[49] HAJJ MEL, BAGHDADI N, ZRIBI M, et al. Synergic use of Sentinel-1 and Sentinel-2 Images for operational soil moisture mapping at high spatial resolution over agricultural areas[J]. Remote Sensing, 2017, 9(12): ID 1292.
[50] HAN D, WANG P, TANSEY K, et al. Linking an agrometeorological model and a water cloud model for estimating soil water content over wheat fields[J]. Computers and Electronics in Agriculture, 2020, 179: ID 105833.
[51] DUBOIS P C, ZYL J, ENGMAN T. Measuring soil moisture with imaging radars[J]. IEEE Transactions on Geoscience and Remote Sensing, 1995, 33(4): 915-926.
[52] STOGRYN A. Electromagnetic scattering from rough, finitely conducting surfaces[J]. Radio Science, 1967, 2 (4): 415-428.
[53] ULABY F T, MOORE R K, FUNG A K. Microwave remote sensing: Active and passive. Volume 2 - Radar remote sensing and surface scattering and emission theory[M]. Reading, MA: Addison Wesley, 1982.
[54] RICE S O. Reflection of electromagnetic waves from slightly random surfaces[J]. Communications on Pure and Applied Mathematics, 1951, 4(2-3): 351-378.
[55] VORONOVICH A G. Small-slope approximation in wave scattering from rough surfaces[J]. Waves in Random Media, 1985, 6(2): 151-167.
[56] KARTHIKEYAN L, PAN M, WANDERS N, et al. Four decades of microwave satellite soil moisture observations: Part 1. A review of retrieval algorithms[J]. Advances in Water Resources, 2017, 109: 106-120.
[57] MO T, CHOUDHURY B J, SCHMUGGE T J, et al. A model for microwave emission from vegetation-covered fields[J]. Journal of Geophysical Research Oceans, 1982, 87(C13): 11229-11237.
[58] JACKSON T J, SCHMUGGE T J, et al. Vegetation effects on the microwave emission of soils[J]. Remote Sensing of Environment, 1991, 36(3): 203-212.
[59] RODRIGUEZ-FERNANDEZ N J, AIRES F, RICHAUME P, et al. Soil moisture retrieval using neural networks: Application to SMOS[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(11): 5991-6007.
[60] KOIKE T, NAKAMURA Y, KAIHOTSU I, et al. Development of an advanced microwave scanning radiometer (AMSR-E) algorithm for soil moisture and vegetation water content[J]. Proceedings of Hydraulic Engineering, 2004, 48: 217-222.
[61] KASAHARA M, IMAOKA K, KACHI M, et al. Status of AMSR2 on GCOM-W1[C]// Proc. International Society for Optical Engineering, Edinburgh, USA: SPIE, 2012: ID 853307.
[62] PARINUSSA R M, WANG G, HOLMES T R H, et al. Global surface soil moisture from the microwave radiation imager onboard the Fengyun-3B satellite [J]. International Journal of Remote Sensing, 2014, 35(19/20): 7007-7029.
[63] WAGNER W, HAHN S, KIDD R, et al. The ASCAT soil moisture product: A review of its specifications, validation results, and emerging applications[J]. Meteorologische Zeitschrift, 2013, 22: 5-33.
[64] FERNANDEZ-MORAN R, AL-YAARI A, MIALON A, et al. SMOS-IC: An alternative SMOS soil moisture and vegetation optical depth product [J]. Remote Sensing, 2017, 9(5): ID 457.
[65] ENTEKHABI D, NJOKU E G, NEILL P E O, et al. The Soil Moisture Active Passive (SMAP) mission[J]. Proceedings of the IEEE, 2010, 98(5): 704-716.
[66] NJOKU E G, CROW W, YUEH S, et al. The SMAP mission combined active-passive soil moisture product at 9 km and 3 km spatial resolutions [J]. Remote Sensing of Environment: An Interdisciplinary Journal, 2018, 211: 204-217.
[67] SWATHANDRAN S, ASLAM M. Assessing the role of SWIR band in detecting agricultural crop stress: A case study of Raichur district, Karnataka, India[J]. Environmental Monitoring and Assessment, 2019, 191 (7): 442.
[68] GAO B C. NDWI-A normalized difference water index for remote sensing of vegetation liquid water from

space[J]. Remote Sensing of Environment, 1996, 58 (3): 257-266.

[69] GERHARDS M, SCHLER F M, MALLICK K, et al. Challenges and future perspectives of multi-/hyper-spectral thermal infrared remote sensing for crop water-stress detection: A review[J]. Remote Sensing, 2019, 11 (10): ID 1240.

[70] HAN D, LIU S, DU Y, et al. Crop water content of winter wheat revealed with Sentinel-1 and Sentinel-2 imagery[J]. Sensors, 2019, 19(18): ID 4013.

[71] 吴伶, 刘湘南, 周博天, 等. 利用PROSPECT+SAIL模型反演植物生化参数的植被指数优化模拟[J]. 应用生态学报, 2012, 23(12): 3250-3256..
WU L, LIU X, ZHOU B, et al. Simulation of vegetation indices optimizing under retrieval of vegetation biochemical parameters based on PROSPECT+SAIL model[J]. Chinese Journal of Applied Ecology, 2012, 23(12): 3250-3256.

[72] DAS B, SAHOO R N, PARGAL S, et al. Comparison of different uni- and multi-variate techniques for monitoring leaf water status as an indicator of water-deficit stress in wheat through spectroscopy[J]. Biosystems Engineering, 2017, 160: 69-83.

[73] CLEVERS J, KOOISTRA L, SCHAEPMAN M E. Estimating canopy water content using hyperspectral remote sensing data[J]. International Journal of Applied Earth Observation and Geoinformation, 2010, 12(2): 119-125.

[74] JIN X, KUMAR L, LI Z, et al. A review of data assimilation of remote sensing and crop models[J]. European Journal of Agronomy, 2018, 92: 141-152.

[75] XIE Y, WANG P, BAI X, et al. Assimilation of the leaf area index and vegetation temperature condition index for winter wheat yield estimation using Landsat imagery and the CERES-Wheat model[J]. Agricultural and Forest Meteorology, 2017, 246: 194-206.

[76] HOLZWORTH D P, SNOW V, JANSSEN S, et al. Agricultural production systems modelling and software: Current status and future prospects[J]. Environmental Modelling & Software, 2015: 276-286.

[77] STEDUTO P, HSIAO T C, RAES D, et al. AquaCrop—The FAO crop model to simulate yield response to water: I. concepts and underlying principles[J]. Agronomy Journal, 2009, 101(3): 426-437.

[78] DUCHEMIN B, FIEUZAL R, RIVERA M, et al. Impact of sowing date on yield and water use efficiency of wheat analyzed through spatial modeling and FORMOSAT-2 images[J]. Remote Sensing, 2015, 7(5): 5951-5979.

[79] DUCHEMIN B, MAISONGRANDE P, BOULET G, et al. A simple algorithm for yield estimates: Evaluation for semi-arid irrigated winter wheat monitored with green leaf area index[J]. Environmental Modelling and Software, 2008, 23(7): 876-892.

[80] ALLEN R, PEREIRA L, RAES D. Crop evapotranspiration: Guidelines for computing crop water requirements, FAO irrigation and drainage paper 56[M]. Rome: FAO, 1998.

[81] SILVESTRO P C, PIGNATTI S, YANG H, et al. Sensitivity analysis of the Aquacrop and SAFYE crop models for the assessment of water limited winter wheat yield in regional scale applications[J]. PLoS One, 2017, 12(11): ID e0187485.

[82] 韩萍, 王鹏新, 张树誉, 等. 基于条件植被温度指数的干旱预测研究[J]. 武汉大学学报(信息科学版), 2010, 35(10): 1202-1206.
HAN P, WANG P, ZHANG S, et al. Drought forecasting with vegetation temperature condition index[J]. Geomatics and Information Science of Wuhan University, 2010, 35(10): 1202-1206.

[83] 李俐, 许连香, 王鹏新, 等. 基于条件植被温度指数的夏玉米生长季干旱预测研究[J]. 农业机械学报, 2020, 51(1): 146-154.
LI L, XU L, WANG P, et al. Drought forecasting during maize growing season based on vegetation temperature condition index[J]. Transactions of the CSAM, 2020, 51(1): 146-154.

[84] 张建海, 张棋, 许德合, 等. ARIMA-LSTM组合模型在基于SPI干旱预测中的应用—以青海省为例[J]. 干旱区地理, 2020, 43(4): 1004-1013.
ZHANG J, ZHANG Q, XU D, et al. Application of a combined ARIMA-LSTM model based on SPI for the forecast of drought: A case study in Qinghai province[J]. Arid Land Geography, 2020, 43(4): 1004-1013.

[85] 于洋, 迟道才, 陈涛涛, 等. 基于EMD的BP神经网络在凌河流域旱灾预测中的应用[J]. 沈阳农业大学学报, 2014, 45(1): 68-72.
YU Y, CHI D, CHEN T, et al. Drought forecast application of BP prediction models based on EMD in Ling River Basin[J]. Journal of Shenyang Agricultural University, 2014, 45(1): 68-72.

[86] 郭建平. 农业气象灾害监测预测技术研究进展[J]. 应用气象学报, 2016, 27(5): 620-630.
GUO J. Research progress on agricultural meteorological disaster monitoring and forecasting[J]. Journal of Applied Meteorological Science, 2016, 27(5): 620-630.

[87] 吴熠婷, 江琪, 孟远, 等. 气候变化条件下陕西省不同气候区灌溉对冬小麦减产风险影响评估[J]. 江苏农业科学, 2021, 49(10): 213-222.

WU Y, JIANG Q, MENG Y, et al. Assessment of impact of irrigation in different climatic regions of Shaanxi province on risk of winter wheat yield reduction under climate change[J]. Jiangsu Agricultural Sciences, 2021, 49(10): 213-222.
[88] 刘维, 侯英雨, 吴门新. 基于WOFOST模型的2014年河南省干旱对夏玉米产量的预估[J]. 中国农学通报, 2016, 32(36): 146-151.
LIU W, HOU Y, WU M. Estimate of drought effect on summer maize yield based on WOFOST model in Henan Province in 2014[J]. Chinese Agricultural Science Bulletin, 2016, 32(36): 146-151.
[89] 杨霏云, 郑秋红, 李文科, 等. 基于WOFOST模型的辽宁省春玉米干旱灾损风险评估[J]. 干旱地区农业研究, 2020, 38(6): 218-225.
YANG F, ZHENG Q, LI W, et al. Risk assessment of drought damage of spring maize in Liaoning province based on WOFOST model[J]. Agricultural Research In The Arid Areas, 2020, 38(6): 218-225.
[90] 王治海, 刘建栋, 刘玲, 等. 基于遥感信息的区域农业干旱模拟技术研究[J]. 水土保持通报, 2013, 33(5): 96-100.
WANG Z, LIU J, LIU L, et al. Regional agro-drought simulation based on remote sensing technology[J]. Bulletin of Soil and Water Conservation, 2013, 33(5): 96-100.

Progress of Agricultural Drought Monitoring and Forecasting Using Satellite Remote Sensing

HAN Dong, WANG Pengxin*, ZHANG Yue, TIAN Huiren, ZHOU Xijia

(*College of Information and Electrical Engineering*, *China Agricultural University*, *Beijing* 100083, *China*)

Abstract: Agricultural drought is a major factor that affects agricultural production. Traditional agricultural drought monitoring is mainly based on meteorological and hydrological data, and although it can provide more accurate drought monitoring results at the point level, there are still limitations in monitoring agricultural drought at the regional scale. The rapid development of remote sensing technology has provided a new mean of monitoring agricultural droughts at the regional scale, especially since the electromagnetic wavelengths sensed by satellite sensors in orbit now cover visible, near-infrared, thermal infrared and microwave wavelengths. It is important to make full use of the rich surface information obtained from satellite remote sensing data for agricultural drought monitoring and forecasting. This paper described the research progress of agricultural drought monitoring based on satellite remote sensing from three aspects: remote sensing index-based method, soil water content method and crop water demand method. The research progress of agricultural drought monitoring based on remote sensing index-based method was elaborated from five aspects: vegetation drought index, temperature drought index, integrated vegetation and temperature drought index, water drought index and microwave drought index; the research progress of agricultural drought monitoring based on soil water content method was elaborated from two aspects: soil water content retrieval based on visible to thermal infrared data and soil water content retrieval based on microwave data; the research progress of agricultural drought monitoring based on crop water demand method was elaborated from two aspects: agricultural drought monitoring based on crop canopy water content retrieval method and crop growth model method. Agricultural drought forecasting is a timeline prediction based on drought monitoring. Based on the summary of the progress of drought monitoring, the research progress of agricultural drought forecasting by the drought index method and the crop growth model method was further briefly described. The existing agricultural drought monitoring methods based on satellite remote sensing were summarized, and its shortcomings were sorted out, and some prospects were put forward. In the future, different remote sensing data sources can be used to combine deep learning methods with crop growth models and based on data assimilation methods to further explore the potential of satellite remote sensing data in the monitoring of agricultural drought dynamics, which can further promote the development of smart agriculture.

Key words: satellite; remote sensing; agricultural drought; crop growth model; monitor; forecast